

OPTIMIZACIÓN DE REDES NEURONALES ARTIFICIALES PARA LA RECONSTRUCCIÓN DEL ESPECTRO DE NEUTRONES Y SUS DOSIS EQUIVALENTES

Arturo Reyes Alfaro¹, José Manuel Ortíz-Rodríguez¹, Alfredo Reyes-Haro¹, Rodrigo Castañeda-Miranda¹, Luis Octavio Solís-Sánchez¹, Héctor René Vega-Carrillo^{1,2}.

¹ Unidad Académica de Ingeniería Eléctrica
Universidad Autónoma de Zacatecas
Av. López Velarde #801, Col. Centro Zacatecas, Zacatecas México, C.P. 98000
art8291@hotmail.com, morvymm@yahoo.com.mx, alfredo_reyesh@hotmail.com

² Unidad Académica de Estudios Nucleares
Universidad Autónoma de Zacatecas
C. Cipres 10 Fracc. La Penuela C.P. 98068 Zacatecas, Zacatecas Mexico)
fermineutron@yahoo.com.

Resumen

En el presente trabajo se utilizó la metodología de diseño robusto de redes neuronales artificiales para determinar una topología óptima de red capaz de resolver con eficiencia los problemas de espectrometría y dosimetría de neutrones. Para el diseño de la topología de red optimizada se entrenaron 36 distintas arquitecturas de red en base a un arreglo ortogonal con una configuración $L_9(3^4)$, $L_4(3^2)$. Para el entrenamiento de las redes neuronales, se utilizó un código de cómputo desarrollado en el entorno de programación de Matlab, el cual automatiza el procesamiento y análisis de la información, reduciendo considerablemente el tiempo empleado en esta actividad para el investigador. Para el entrenamiento de las redes de propagación hacia adelante se utilizó un compendio de espectro de neutrones publicado por la Agencia Internacional de Energía Atómica, donde del total se utilizaron el 80% para el entrenamiento y 20% para la prueba, entrenada con un algoritmo de propagación inversa siendo los datos de entrada las tasas de conteo correspondientes a las 7 esferas del sistema espectrométrico de esferas Bonner, como datos de salida, la red neuronal obtiene el espectro de neutrones expresado en 60 grupos de energía y se calculan de forma simultánea 15 cantidades dosimétricas.

Palabras clave: Redes Neuronales Artificiales, Espectrometría, Dosimetría, Neutrones, Esferas Bonner, Optimización.

1.- INTRODUCCION

1.1.- Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (RNA) están inspiradas en el sistema nervioso biológico. Una RNA imita el funcionamiento las neuronas biológicas del cerebro humano y tiene la capacidad para aprender de su entorno y mejorar su desempeño a través de un proceso conocido como aprendizaje, empleando un proceso iterativo de ajustes aplicados a sus pesos sinápticos [Lippmann, 1987; Jain, Mao y Mohiuddin, 1996]. Idealmente, la red se vuelve conocedora de su ambiente después de cada iteración.

La RNA multicapa de propagación inversa es una de las más populares. En este tipo de red, las salidas de una capa se transmiten solo a las capas superiores. Como se muestra en la figura 1, la red está constituida por la capa de entrada, la cual es la que recibe los estímulos del exterior, las capas intermedias conocidas como capas ocultas y la capa de salida, siendo la que muestra el resultado obtenido.

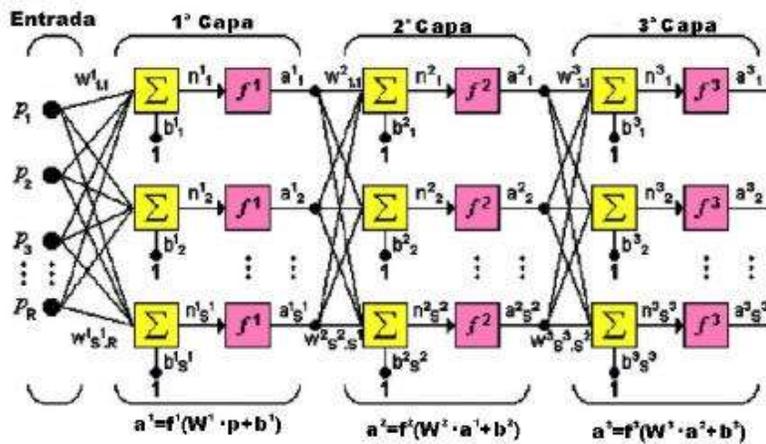


figura 1. Arquitectura de tres capas.

Aunque el algoritmo de aprendizaje de propagación inversa proporciona un método para entrenar redes neuronales, no está libre de problemas, existen factores que afectan el desempeño del aprendizaje [Packianather, Drake y Rowlands, 2000; Packianather y Drake, 2003; Lin y Tseng 2000], por lo que existe la necesidad de resolver estas deficiencias.

Actualmente, se emplea la técnica de ensayo y error para obtener la mejor combinación de la arquitectura y parámetros de la red [Kardan et al., 2003]. Este método ha mostrado ser poco eficiente produciendo redes de pobre desempeño y baja capacidad de generalización.

Determinar un conjunto apropiado de valores de los parámetros es una tarea complicada [Packianather, Drake y Rowlands, 2000; Packianather y Drake 2003; Lin y Tseng 2000]. Para diseñar una red de alto desempeño se debe considerar simultáneamente los parámetros relacionados con el entrenamiento, factores controlables y no controlables. Existen parámetros indeseables en el entrenamiento como el conjunto inicial de pesos, la división y el tamaño de datos entre datos de entrenamiento y prueba.

1.2.- Diseño robusto de RNA

Los Métodos Taguchi fueron desarrollados como una técnica de optimización de procesos por el Dr. Genichi Taguchi, durante los años 50. Los métodos se basan en el análisis estadístico de datos y ofrecen un medio simple de análisis y optimización de sistemas complejos [Packianather, Drake y Rowlands, 2000]. El diseño de experimentos es ampliamente utilizado en la industria de la manufactura como herramienta de control de calidad fuera de línea, donde la calidad se construye dentro del producto, en la etapa de diseño. Las variables independientes en un experimento son los parámetros de diseño y se establecen varios niveles. Están los parámetros que varían intencionalmente, llamados factores controlables, aquellos que sobre los cuales no se tiene control, se llaman factores de ruido o no controlables.

El tamaño y los parámetros de entrenamiento de las RNA tiene un efecto crítico en su desempeño. El método de diseño de experimentos de Taguchi, siendo un método paralelo ofrece beneficios considerables en tiempo y precisión cuando se compara con el método ensayo y error [Packianather, Drake y Rowlands, 2000; Packianather y Drake 2003; Lin y Tseng 2000]. El objetivo de la experimentación robusta en RNA, es encontrar una combinación óptima de las selecciones de los factores de control que alcancen la robustez contra los factores de ruido. La importancia de este proceso consiste en que en medida que se entrena la red, las neuronas de las capas intermedias se organizan a sí mismas de tal

modo que las distintas neuronas aprenden a reconocer diferentes características del espacio.

Los procesos de optimización conocidos como métodos Taguchi se han aplicado al entrenamiento de RNA, realizando una comparación entre la eficiencia del entrenamiento de éstos y la de los métodos de entrenamientos convencionales. En base el método por Taguchi se emplea el algoritmo diseñado por Ortiz-Rodríguez en 2005 para resolver problemas de diseño robusto de redes neuronales artificiales del tipo "propagación inversa" [Ortiz-Rodríguez et al., 2005a; Ortiz-Rodríguez 2005b].

Las RNA se han utilizado en diversas áreas de la ciencia e ingeniería para realizar diferentes tareas como el reconocimiento de imágenes, de voz, de patrones, planeación, predicción, y actualmente también en la protección radiológica, más concretamente en la resolución del espectro de neutrones.

1.3.- Espectro de neutrones

El termino espectrometría de radiación puede ser usada para describir la medición de la intensidad de un campo de radiación con respecto a la energía, la frecuencia o momento. La distribución de la intensidad con uno de los parámetros se conoce comúnmente como el "espectro". Una segunda cantidad es la variación de la intensidad de estas radiaciones como una función del ángulo de incidencia sobre un cuerpo situado en el campo de radiación es referido como "dosis". El espectro de neutrones y sus dosis son tareas de gran importancia en la física de radiación [Thomas, 2004]. Determinar las dosis de neutrones recibida requiere conocimiento sobre el espectro de neutrones, la información del espectro debe generalmente ser obtenida por detectores pasivos los cuales responden a diferentes rangos de energía de los neutrones, como el sistema Espectrométrico de Esferas Bonner (SEEB).

El SEEB está compuesto de un sensor de neutrones térmicos de ${}^6\text{LiI}(\text{Eu})$, que se coloca en el centro de un número de esferas de polietileno de diámetro diferente, donde cada par detector-esfera se caracteriza por su función de respuesta. La combinación de un detector de neutrones térmicos mas la esfera de cierto diámetro tiene una sensibilidad a lo largo de

un rango de energía. A medida que aumenta el tamaño de la esfera, se desplaza el máximo de la función de respuesta a las energías, por lo tanto, la sensibilidad del pico en la energía de neutrones depende del diámetro de estas, conformando una matriz de respuesta. La matriz se utiliza junto con las tasas de conteo del detector para determinar el espectro de neutrones, debido a que el número de esferas es pequeño y los intervalos de clase de la energía de los neutrones es grande, el problema se traduce en resolver la ecuación de Fredholm de primera clase, cuya versión discreta se muestra en la ecuación 1 [Kardan et al., 2003].

$$C_j = \sum_{i=1}^N R_{i,j} \Phi_i \quad J = 1, 2, \dots, m \quad (1)$$

Donde C_j es la tasa de conteo del j-ésimo detector, $R_{(i,j)}$ es la matriz de respuesta del j-ésimo detector de neutrones en el i-ésimo intervalo de energía, $\Phi_{(i)}$ es la fluencia de neutrones en el i-ésimo intervalo de energía y m es el numero de esferas del sistema espectrométrico.

Para reconstruir el espectro es necesario resolver el sistema de ecuaciones para lo cual se emplean varios procedimientos como el de Monte Carlo, de parametrización. Por sus dificultades, se ha motivado la búsqueda de alternativas, como los métodos basados en la máxima entropía, algoritmos genéticos [Mukherjee, 2002; Freeman, Edwards y Bolon, 1999] y RNA [Fausett, 1993; Gupta, Jin y Homma, 2003; Lippmann, 1987].

En este trabajo se utiliza la tecnología de RNA para resolver el espectro de neutrones y calcular de forma simultánea 15 cantidades dosimétricas, utilizando como única pieza de información de entrada las tasas de conteo del SEEB [Bramblett, Ewing y Bonner, 1960; Vylet, 2002].

2.- MATERIALES Y METODOS

En el presente proyecto, se utilizan los procesos de optimización Taguchi en la selección óptima de los parámetros de la arquitectura de una red neuronal artificial aplicada en el ámbito de la espectrometría y dosimetría de neutrones. Estos métodos de optimización ofrecen beneficios potenciales en la evaluación del comportamiento de la red así como la habilidad para examinar la interacción de los pesos y neuronas. El diseño robusto de redes neuronales artificiales evalúa cuál de los diferentes factores variables tienen el mayor efecto sobre el resultado deseado y se compone de las siguientes etapas: Planeación, experimentación, análisis y confirmación [Shyam, 2002].

2.1.- Etapa de planeación

En la etapa de planeación es necesario identificar las características de desempeño de las variables de diseño y las variables de ruido en la función del objetivo es la salida del error cuadrático medio (mse) de la arquitectura de la RNA como se muestra en la ecuación (2).

$$MSE = \sqrt{\frac{1}{N} \sum_i^N \left(\Phi_E(E)_i^{RNA} - \Phi_E(E)_i^{ORIGINAL} \right)^2} \quad (2)$$

Cuando N es el número de ensayos, $\Phi_E(E)_i^{ORIGINAL}$ es el espectro original y $\Phi_E(E)_i^{RNA}$ es el espectro reconstruido en la RNA.

2.2.1.- Factores controlables

Se seleccionaron cuatro variables de diseño, como se muestra en la tabla 1, en términos de la experimentación Taguchi. Se consideraron tres niveles para cada variable de diseño, para diseñar la estructura de una red de este tipo, se seleccionó el número de neuronas en la primera (A) y segunda (B) capas ocultas. Se considera que con una o dos capas ocultas son suficientes para capturar complicadas relaciones entrada-salida. La tasa de aprendizaje (C) y el momento (D) siendo los parámetros más importantes controlables que tienen influencia en el desempeño de la red [Packianather, Drake y Rowland, 2000].

Tabla 1.- Variables de diseño y sus niveles.

Variables	Nivel	Nivel	Nivel
De diseño	1	2	3
A			
B			
C			
D			

Donde A es el numero de neuronas en la capa oculta 1, B el numero de neuronas en la capa oculta 2, C es la tasa de aprendizaje y D es el momento.

2.2.2.- Factores no controlables

Existen fuentes de ruido en los experimentos, por el conjunto aleatorio inicial de pesos sinápticos y el ruido aportado por el conjunto de entrenamiento y prueba. En la tabla 2 se muestran las variables de ruido seleccionado por dos niveles cada una, como son el conjunto inicial de pesos (U) y el tamaño de porcentaje de datos que deberían asignarse para el conjunto de entrenamiento comparado con el tamaño de porcentaje de datos que deberían asignarse para el conjunto de prueba (V).

Tabla 2.- Variables de ruido y sus niveles

Variables	Nivel	Nivel
De ruido	1	2
U	Conjunto 1	Conjunto 2
V	E:P	E:P
W	Entr1/prue1	Entr2/Prue2

Donde U es el conjunto inicial de pesos aleatorios, V es la relación del tamaño de datos de entrenamiento y prueba y W es la selección aleatoria de los conjuntos de entrenamiento y prueba

2.3.- Etapa de Experimentación

Para un diseño experimental, el método Taguchi sugiere un arreglo ortogonal cruzado. El arreglo Taguchi se denota como $L_r(C^s)$ donde r es el número de renglones, c es el número de columnas y S es el número de niveles en cada columna. Dado que se contemplaron cuatro variables de diseño, un experimento factorial completo estaría compuesto de $3^4 = 81$ experimentos. El diseño factorial fraccionado mínimo, requiere nueve experimentos, haciendo uso del arreglo ortogonal $L_9(3^4)$, $L_4(2^3)$, como puede observarse en la tabla 3.

Tabla 3.- Parámetros de optimización de la RNA.

Exp. No.	A	B	C	D	S1	S2	S3	S4	Promedio	Relacion S/R
1	1	1	1	1						
2	1	2	2	2						
3	1	3	3	3						
4	2	1	2	3						
5	2	2	3	1						
6	2	3	1	2						
7	3	1	3	2						
8	3	2	1	3						
9	3	3	2	1						

2.3.- Etapa de Análisis

En la i -ésima ejecución del arreglo ortogonal diseñado, se calculó la relación señal-ruido en base a los resultados obtenidos en la ejecución de los experimentos. Las relaciones señal-ruido se analizan por medio de la técnica del análisis de la varianza, para determinar los efectos significativos, y los niveles óptimos de las variables de diseño. Se tomó la medición de la exactitud de la clasificación de los datos de prueba, para el diseño de la red neuronal, con la relación señal-ruido donde la relación deseable de señal-ruido es aquella que tiene el valor más grande. El análisis estadístico se realizó mediante el programa JMP.

2.3.- Etapa de Confirmación

En la fase de confirmación se utilizó la herramienta JPM para seleccionar los mejores valores del diseño de la RNA final.

3.- RESULTADOS

Se aplicó la estrategia de diseño robusto de Taguchi a un grupo de espectros de neutrones, compilados por el Organismo Internacional de Energía Atómica, seleccionándolos de acuerdo con la forma de onda de los espectros del grupo correspondiente al arreglo ortogonal. Se construyó y entrenó una red neuronal de propagación hacia adelante con algoritmo de propagación inversa, con el algoritmo de entrenamiento trainscg y un error de 10^{-4} , usando el arreglo ortogonal $L_9(3^4)$, $L_4(2^3)$ para las variables de diseño y de ruido respectivamente, probándolas posteriormente para obtener las relaciones de señal a ruido (S/R).

3.1.- Etapa de planeación

Se seleccionó las variables de diseño y de ruido, como se muestra en la tabla 4 y 5.

Tabla 4.- Variables de diseño y sus niveles.

Variables de diseño	Nivel 1	Nivel 2	Nivel 3
A	12	14	16
B	0	14	16
C	0.001	0.1	0.3
D	0.001	0.05	0.1

Tabla 5.- Variables de ruido y sus niveles

Variables de ruido	Nivel 1	Nivel 2
U	Conjunto 1	Conjunto 2
V	8:2	8:2
W	Entr1/prue1	Entr2/Prue2

3.2.- Etapa de experimentación

Se entrenó y probó 36 arquitecturas RNAs diferentes, obteniendo el valor de la función objetivo, es decir, el error mse establecido en la fase de planificación. La configuración se muestran en la tabla 6 donde valores de respuesta son las diferentes actuaciones RNAs arquitectura entrenados y probados.

Tabla 6.- Parámetros de optimización de la RNA.

Exp. No.	Resp. 1	Resp. 2	Resp. 3	Resp. 4	Promedio	Relacion S/R
1	0.0001541	0.0001318	0.0002364	0.0001303	0.00016322	-10.568006
2	0.0001797	0.0002186	0.0001569	0.0002186	0.00019349	-16.13384
3	0.0001501	0.0002570	0.0002980	0.0002264	0.00023293	-11.658864
4	0.0001784	0.0002035	0.0001618	0.0002050	0.00018722	-19.099823
5	0.0001336	0.0003422	0.0002630	0.0003422	0.00027031	-9.1813986
6	0.0001574	0.0002971	0.0001057	0.0002971	0.00021437	-7.4413861
7	0.0001795	0.0001857	0.0003555	0.0001857	0.00022667	-8.8657194
8	0.0002759	0.0002076	0.0001477	0.0002076	0.00020974	-12.245592
9	0.0001684	0.0001475	0.0001699	0.0002812	0.00019173	-10.346194

2.2.- Etapa de análisis y confirmación

La relación de la señal a ruido obtenida en la etapa de experimentación, mediante el software estadístico JMP, se utilizo en esta etapa para determinar los niveles óptimos de la RNA para construir la arquitectura robusta RNA. con ello, y utilizando la JMP se calcularon los mejores RNA de diseño, como se muestra en la tabla 7.

Tabla 7.- Valores optimizados de las RNA

RNA	A	B	C	D
1	10	0	0.001	0.01
2	12	14	0.3	0.1

Una vez hecha la selección de los parámetros con los mejores niveles para el diseño de la RN, se entrenó y probó con los mismos, observándose que la selección $A = 10$, $B = 0$, $C = 0.001$ y $D = 0.01$ entrenada y simulada con el 80% y 20% respectivamente de la información total disponible, presentaba los mejores resultados. Siendo entrenada en varias ocasiones la red para elegir la mejor posible.

En las figuras 2, 3 y 4 se muestran las características de los experimentos de la arquitectura de red seleccionada.

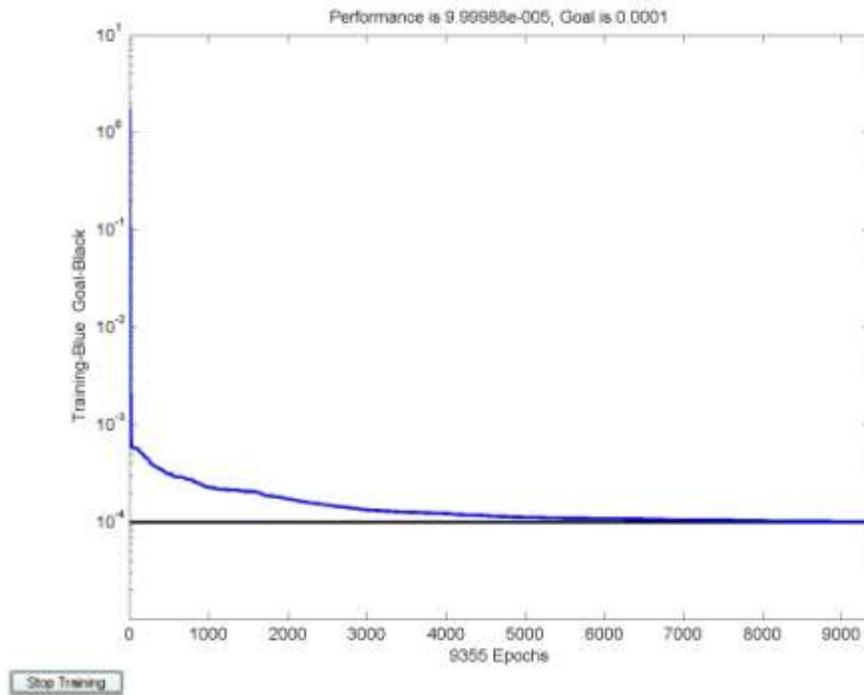


Figura 2.- Error = 10^{-4} y el numero de iteraciones del entrenamiento.

En la figura 2 se muestra el proceso del entrenamiento de la red durante 175.875 segundos, se puede observar que se llega al error deseado de 10^{-4} , alrededor de las seis mil iteraciones.

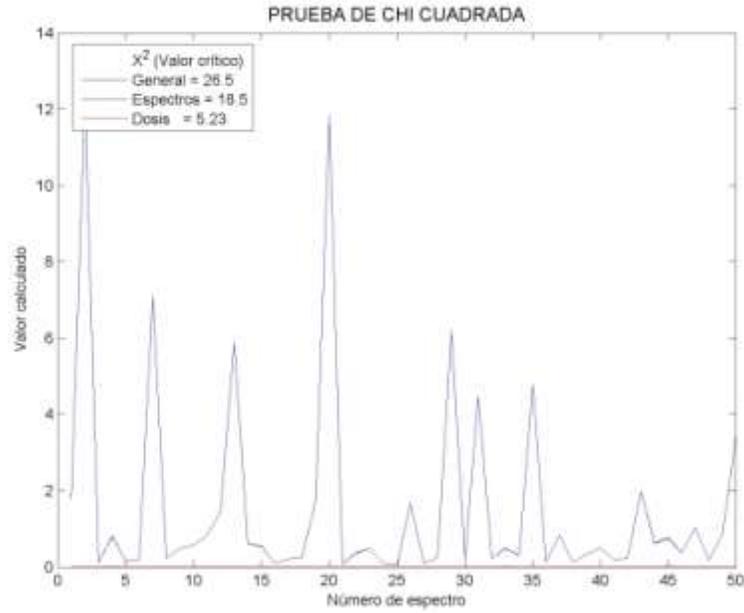


Figura 3.- Prueba de CHI cuadrada.

En la figura 3 se muestra la prueba de chi cuadrada, donde se busca que los valores sean cercanos a cero y la mayoría de los valores lo alcanzan.

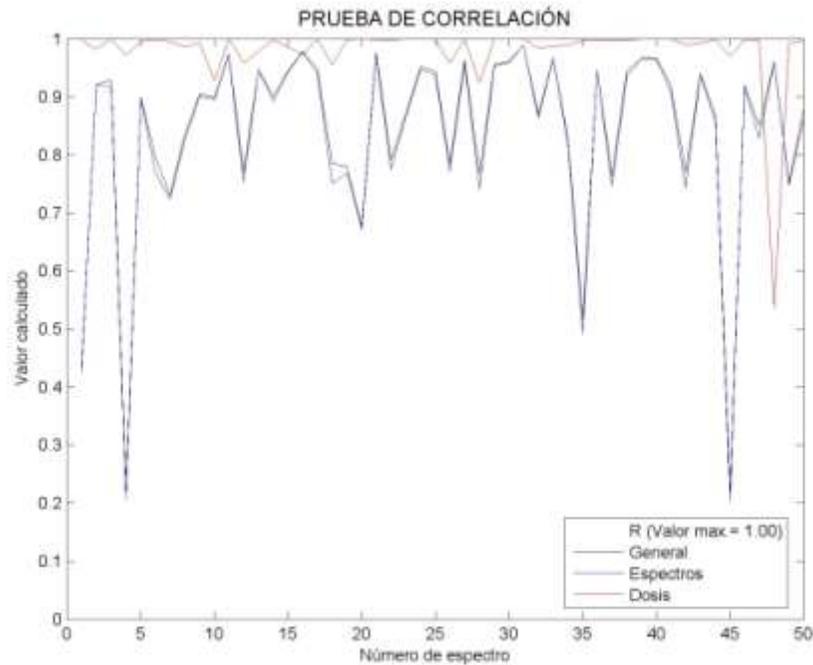


Figura 4.- Prueba de correlación.

En la tabla 7 se muestran las dosis equivalentes calculadas mientras que de la figura 5 a la 12 se muestra la comparación de los dos peores y los dos mejores casos del espectro obtenido contra el espectro esperado, del entrenamiento de la red.

Tabla 7.- Valores optimizados de las RNA

Num	Dosis	Descripción
1	E_{AP}	Dosis efectiva anterior-posterior
2	E_{PA}	Dosis efectiva posterior-anterior
3	E_{RLAT}	Dosis efectiva lateral derecha
4	E_{ROT}	Dosis efectiva rotacional
5	E_{ISO}	Dosis efectiva isotrópica
6	$H_*(10)$	Dosis ambiental equivalente
7	$H_p,slab(10,0^\circ)$	Dosis personal equivalente a 0°
8	$H_p,slab(10,45^\circ)$	Dosis personal equivalente a 45°
9	$H_p,slab(10,60^\circ)$	Dosis personal equivalente a 60°
10	$H_p,slab(10,75^\circ)$	Dosis personal equivalente a 75°
11	HE_{AP}	Dosis efectiva equivalente anterior-posterior
12	HE_{PA}	Dosis efectiva equivalente posterior-anterior
13	HE_{ROT}	Dosis efectiva equivalente rotacional
14	HE_{LAT}	Dosis efectiva equivalente lateral

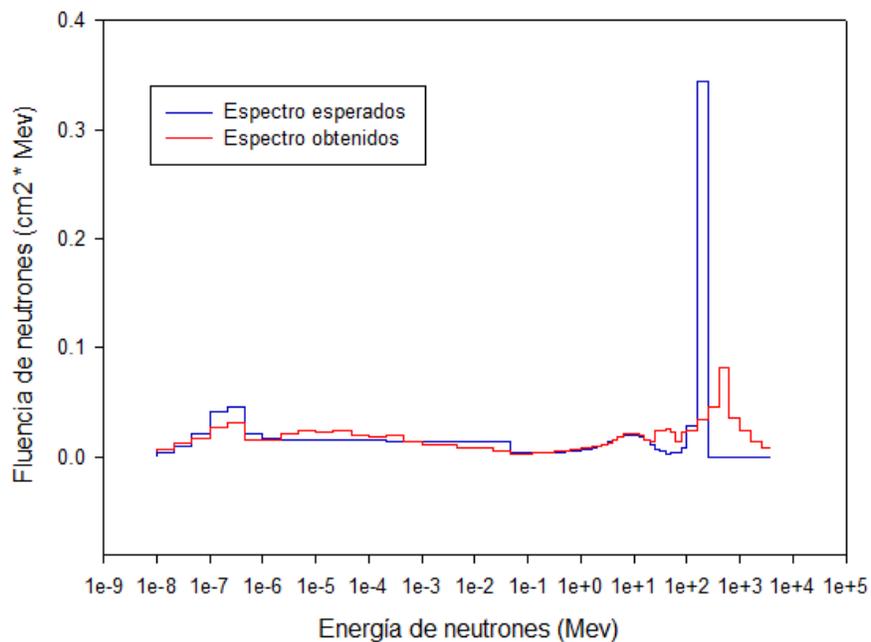


Figura 5.- Comparación del peor caso del espectro obtenido con el esperado.

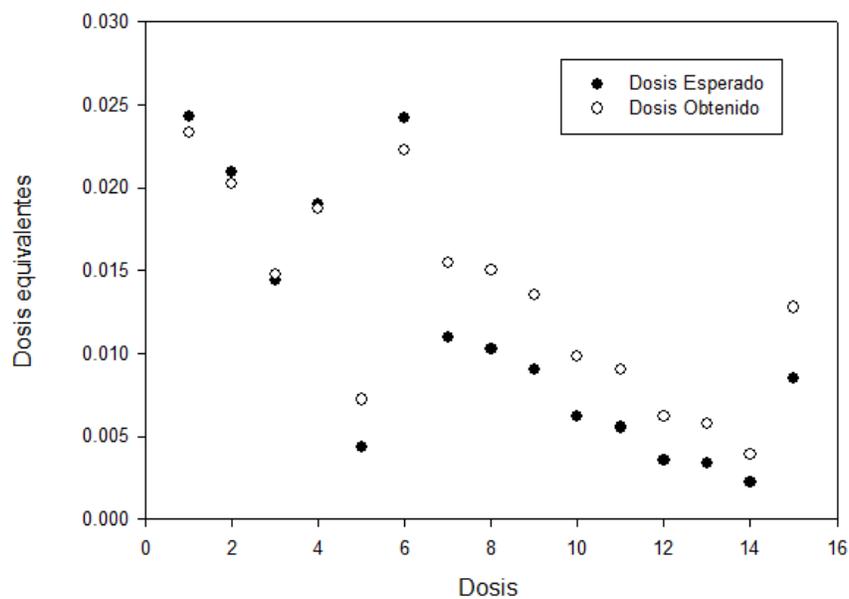


Figura 6.- Comparación del peor caso de las dosis obtenidas contra las esperadas.

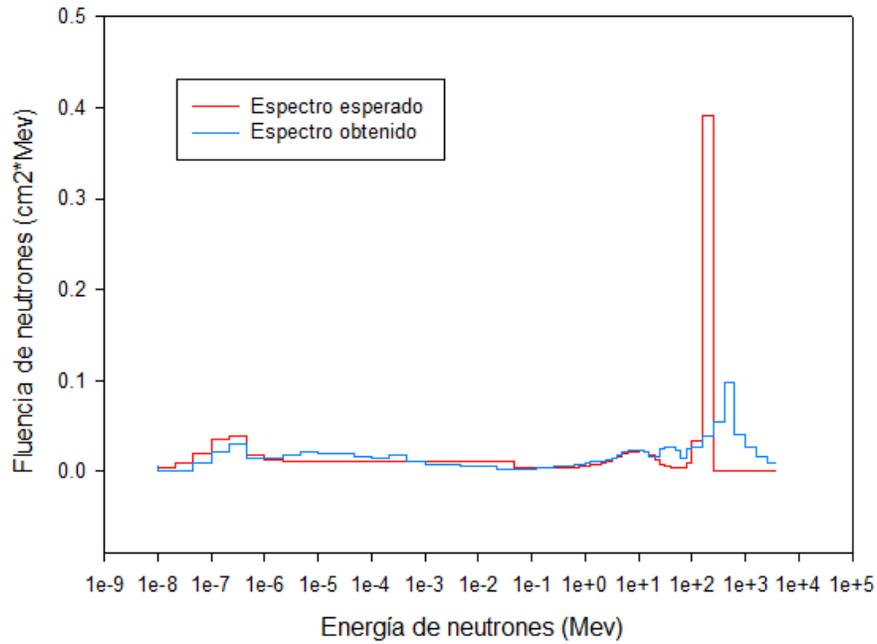


Figura 7.- Comparación del segundo peor caso del espectro obtenido con el esperado.

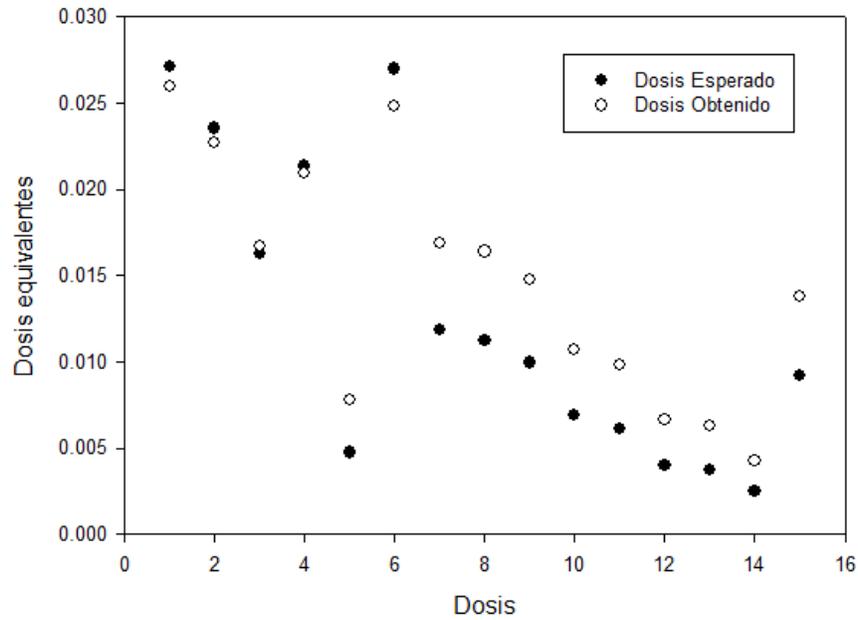


Figura 8.- Comparación del segundo peor caso de las dosis obtenidas contra las esperadas.

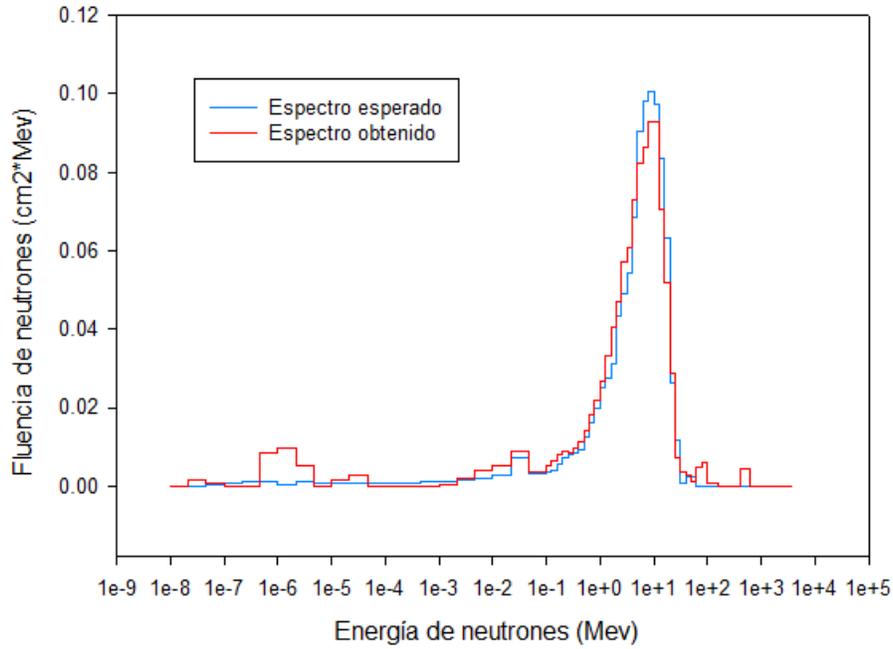


Figura 9.- Comparación del mejor caso del espectro obtenido con el esperado.

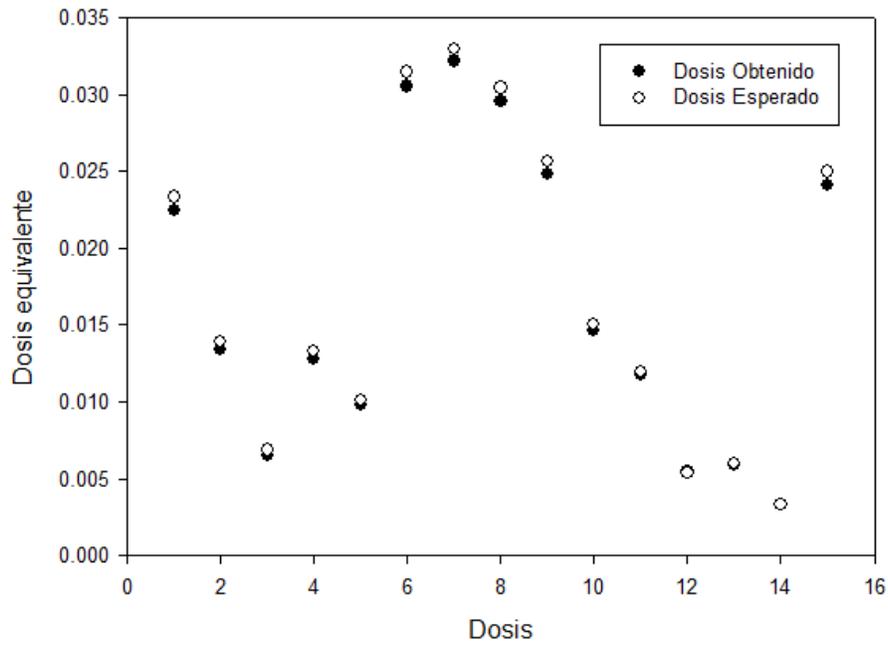


Figura 10.- Comparación del mejor caso de las dosis obtenidas contra las esperadas.

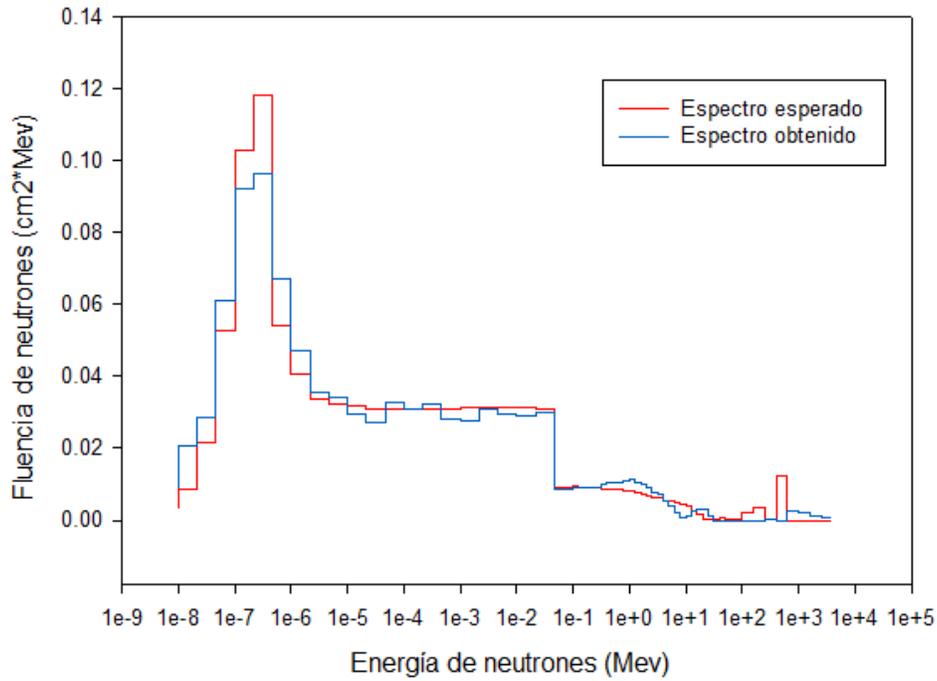


Figura 11.- Comparación del segundo mejor caso del espectro obtenido con el esperado.

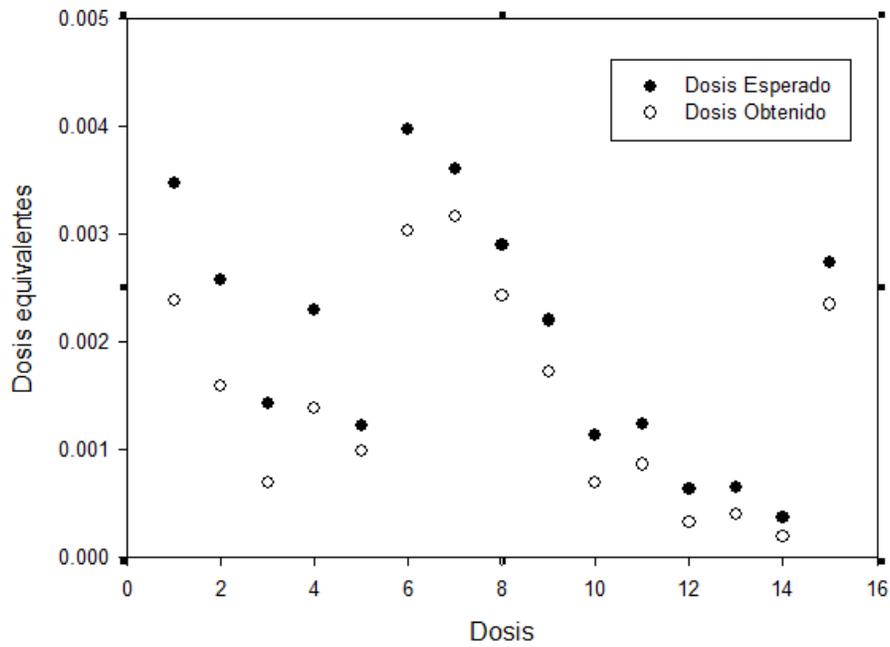


Figura 12.- Comparación del segundo mejor caso de las dosis obtenidas contra las esperadas.

4.- DISCUSIÓN

El método propuesto difiere del convencional en que adopta una estrategia sistemática experimental, considerando la robustez de la red, características que generalmente no se consideran en el método convencional. Se identifican los parámetros de diseño y de ruido, haciendo uso del diseño robusto de Taguchi para encontrar los mejores parámetros de diseño de las RNA con un número mínimo de experimentos, usando un arreglo ortogonal.

5.- CONCLUSIONES

En este trabajo, se experimento el llamado Diseño robusto de Redes Neuronales Artificiales, como una nueva herramienta para espectrometría y dosimetría de neutrones, para encontrar las mejores parámetros de diseño RNA. Con esta metodología, los usuarios tienen que reconocer el problema de diseño y elegir una red adecuada.

La primera etapa para el método de Taguchi incluye la identificación de la función objetivo del Diseño robusto y para identificar el diseño y variables de ruido y sus niveles. Entre los diversos parámetros que afectan al rendimiento de la RNA, cuatro variables de diseño que seleccionó. Para el diseño experimental, que corresponde a la etapa experimental, se utilizaron matrices ortogonales. Las RNA fueron entrenadas y probadas usando una herramienta desarrollada en Matlab para este propósito. Usando el programa estadístico JMP, se obtienen los niveles óptimos de la RNA.

La aplicación del diseño robusto ha conducido a la identificación de un conjunto de parámetros de diseño y arquitectura de capas múltiples con propagación hacia adelante formados por algoritmos de propagación inversa para producir un rendimiento mucho mejor. La topología RNA obtenido con el Diseño robusto es la siguiente: 7:10:75 con un momento = 0,1 y una tasa de aprendizaje = 0,001, MSE = 1e-4 y una función de aprendizaje.

A diferencia de otras obras, con el uso de la metodología de Diseño robusto el tiempo dedicado a determinar la arquitectura optima de las RNAs, se reduce significativamente. Se

necesita de minutos a un par de horas para determinar los mejores parámetros de RNA.

Agradecimientos

Se agradece el financiamiento recibido por PROMEP bajo el contrato PROMEP/103.5/12/3603, así como al Consejo Zacatecano de Ciencia y Tecnología por el apoyo recibido.

REFERENCIAS

- Bramblett, R.L.; Ewing, R.I. and Bonner T.W. (1960). *A new type of neutron spectrometer*. Nuclear Instruments and Methods **9**: 1–12.
- Fausett, L. *FUNDAMENTALS OF NEURAL NETWORKS*. Prentice-Hall (1993).
- Freeman, D.W.; Edwards, D.R. and Bolon, A.E. (1999). *Genetic algorithms - A new technique for solving the neutron spectrum unfolding problem*. Nuclear Instruments and Methods in Physics Research A **425**: 549-576.
- Gupta, M.M.; Lin, J. and Homma, N. *STATIC AND DYNAMIC NEURAL NETWORKS FROM FUNDAMENTALS TO ADVANCED THEORY*. John Wiley & Sons (2003).
- Jain, A.K.; Mao, J. and Mohiuddin, K.M. (1996). *Artificial neural networks: a tutorial*, IEEE Computer **29**: 31-44.
- Kardan, M.R.; Setaycshi S.; Koochi-Fayegh R. and Ghiassi-Nejad M. (2003). *Neutron spectra unfolding in Bonner spheres spectrometry using neural networks*. Radiation Protection Dosimetry **104**: 27-30.
- Lin, T.Y. and Tseng, C.H. (2000). *Optimum design for artificial neural networks: an example in a bicycle derailleur system*. Engineering Applications of Artificial Intelligence **13**: 3-14.
- Lippmann R.P. (1987). *An introduction to computing with neural networks*, IEEE ASSP Magazine **4**: 4-21.
- Mukherjee, B. (2002). *A high-resolution neutron spectrum unfolding method using the Genetic algorithm technique*. Nuclear Instruments and Methods in Physics Research A **476**: 247-251.
- Ortiz-Rodríguez, J.M., Martínez-Blanco, M.R., Arteaga- Arteaga, T., Vega-Carrillo, H.R., Hernández-Dávila, V.M. y Manzanares-Acuña, E. (2005a), *Reconstrucción de espectros de neutrones usando redes neuronales a partir del sistema espectrométrico de esferas de Bonner*. VIII International Symposium/XVIII National Congress on Solid State Dosimetry. Zacatecas, Zac. Mexico.

- Ortiz-Rodríguez, J.M. (2005b). *Diseño robusto de redes neuronales aplicadas en la espectrometría de neutrones*. Tesis de Maestría, Universidad Autónoma de Zacatecas.
- Packianather M.S. and Drake P.R. (2003). *Modelling neural network performance through response surface methodology for classifying wood veneer defects*. Journal of Engineering Manufacture **218**: 459-466.
- Packianather M.S., Drake, P.R. and Rowlands, H. (2000). *Optimizing the parameters of multilayered feedforward neural networks through Taguchi design of experiments*. Quality and Reliability Engineering International **16**: 461-473
- Shyam, M.N. (2002). *Robust Design*. Seminar Report.
- Thomas, J.D. (2004). *Neutron spectrometry for radiation protection*, Radiation Protection Dosimetry **110**: 141-149.
- Vylet, V. (2002). *Response matrix of an extended Bonner sphere system*. Nuclear Instruments and Methods in Physics Research A **479**: 26–30.